

文章编号: 1001-0920(2008)03-0302-04

电梯群控系统交通需求的迭代学习预测方法

杨祯山, 邵 诚, 马海丰

(大连理工大学 电子与信息工程学院, 辽宁 大连 116024)

摘 要: 提出对时变垂直交通需求的智能化迭代学习预测方法. 该方法采用最小二乘支持向量机技术, 动态预测未来的交通需求及其变化规律. 在此基础上, 提出以电梯交通需求净增量及其变化率强度为依据的交通模式划分的新规则. 通过构造滤波函数的方法获取交通需求变化的主要信息, 对交通模式量化识别, 得到主要交通模式区间的临界点. 仿真实验表明了该方法的有效性.

关键词: 电梯群控系统; 交通需求预测; 迭代学习; 最小二乘支持向量机; 滤波函数; 交通模式识别

中图分类号: TP391

文献标识码: A

Prediction of traffic demand for elevator group control system using iterative learning

YANG Zhen-shan, SHAO Cheng, MA Hai-feng

(Institute of Advanced Control Technology, Dalian University of Technology, Dalian 116024, China. Correspondent: YANG Zhen-shan, E-mail: zsyang3@tom.com)

Abstract: A least squares support vector machine (LS-SVM) based intelligent prediction method is proposed which uses iterative learning to deal with the varying elevator traffic. The future traffic demand is forecasted dynamically to find the varying regular pattern. A new principle of traffic pattern recognition based on the net increment and the intensity of gradient change of the traffic demand is presented. By constructing filter function of the traffic difference, the principal features of the varying traffic demand are extracted and the traffic pattern recognition is conducted to obtain the principal traffic pattern critical points. Simulation experiments show the effectiveness of the proposed method.

Key words: Elevator group control system; Traffic demand prediction; Iterative learning; Least squares support vector machine; Filter function; Traffic pattern recognition

1 引 言

交通需求预测主要研究电梯群控系统交通状况, 利用时间序列观测数据, 估计未来的交通状况^[1,2].

在电梯交通需求预测的研究中, 国内外专家尝试用多种方法来解决这一问题^[3-5]. 主要有神经网络、指数平滑等方法. 指数平滑法是基于加权平均的思想, 与模糊逻辑相结合进行模式识别, 是一种静态的预测方法, 难以适应时变的交通需求. 神经网络与模糊逻辑相结合用于交通预测取得了一定的进展, 存在不足是网络自身结构难以确定, 参数训练复杂、过拟合和陷入局部极值等. 因此对交通需求预测新

方法的研究至关重要.

以上方法主要是基于经验风险最小化的原则, 可以较好地拟合观测数据, 但预测能力相对不足. 而基于结构风险最小化原则的支持向量机技术, 恰恰弥补了这些方法的不足. 研究表明^[1,6]: 97% 的交通需求变化都可解释为周期性变化. 这为交通需求预测奠定了必要的基础.

本文提出对时变交通需求预测的智能化迭代学习方法和交通模式划分的新规则, 动态预测未来交通需求及其变化规律, 并据此给出主要交通模式的时间临界点, 指导电梯群控系统动态调整控制策略, 提高电梯群控系统的整体效率.

收稿日期: 2006-11-20; 修回日期: 2007-02-06.

基金项目: 国家自然科学基金项目(69874026); 国家科技攻关计划项目(2001BA204B01); 辽宁省重点实验室基金项目.

作者简介: 杨祯山(1965—), 男, 辽宁锦州人, 教授级高级工程师, 博士生, 从事复杂系统、先进控制技术的研究; 邵诚(1958—), 男, 江苏靖江人, 教授, 博士生导师, 从事复杂系统、自适应控制等研究.

2 LS-SVM 支持向量机回归原理

LS-SVM 是标准支持向量回归机的一种扩展^[7],其模型为

$$\min_{w,b,e} \frac{1}{2} w^T w + \frac{C}{2} \sum_{i=1}^l e_i^2, \quad C > 0,$$

$$\text{s. t. } y_i = w^T(x_i) + b + e_i, \quad i = 1, 2, \dots, l. \quad (1)$$

其中: 训练样本 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ ($X \times Y$)^l, $x_i \in X = R^n, y_i \in Y = R, l$ 为样本总数, n 为空间维数, C 为正则化参数. 相应的 Lagrange 函数为

$$L(w, b, \lambda) = \frac{1}{2} w^T w + \frac{C}{2} \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \lambda_i \{w^T(x_i) + b + e_i - y_i\},$$

式中 λ_i 为 Lagrange 乘子. 从而可知 KKT 条件为

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \Leftrightarrow w = \sum_{i=1}^l \lambda_i x_i, \\ \frac{\partial L}{\partial b} = 0 \Leftrightarrow \sum_{i=1}^l \lambda_i = 0, \\ \frac{\partial L}{\partial e_i} = 0 \Leftrightarrow \lambda_i = C e_i, \\ \frac{\partial L}{\partial \lambda_i} = 0 \Leftrightarrow w^T(x_i) + b + e_i - y_i = 0, \\ i = 1, 2, \dots, l. \end{cases} \quad (2)$$

式(2)可表示成如下线性关系式:

$$\begin{bmatrix} 0 & \mathbf{1}^T \\ \mathbf{1} & K + \frac{1}{C}I \end{bmatrix} \begin{bmatrix} b \\ Y \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix}. \quad (3)$$

其中: $Y = [y_1, y_2, \dots, y_l]^T, \mathbf{1} = [1, 1, \dots, 1]^T, I$ 为 $l \times l$ 阶单位矩阵.

这样原回归问题可通过最小二乘法求解, 所得回归函数为

$$y = \sum_{i=1}^N \lambda_i K(x_i, x) + b, \quad (4)$$

其中 $K(x_i, x) = (x_i)^T(x)$.

由于 LS-SVM 使用了最小二乘法, 在一定程度上解决了 SVM 的计算复杂性问题. 利用 LS-SVM, 对电梯交通需求时间序列观测数据进行回归, 获取连续可微的交通需求函数

$$f_n(t) = \sum_{i=1}^N \lambda_i K(t_i, t) + b,$$

其中 $n = 0, 1, \dots, t$ 为时间变量. 据此预测交通需求的变化规律 $\tilde{f}_n(t), n = 0, 1, \dots$

3 电梯交通需求预测模型的建立

本文提出的交通需求预测及模式识别, 由交通数据观测、预测模型获取、滤波函数构造、模式识别规则的建立等部分组成. 整体流程如图 1 所示.

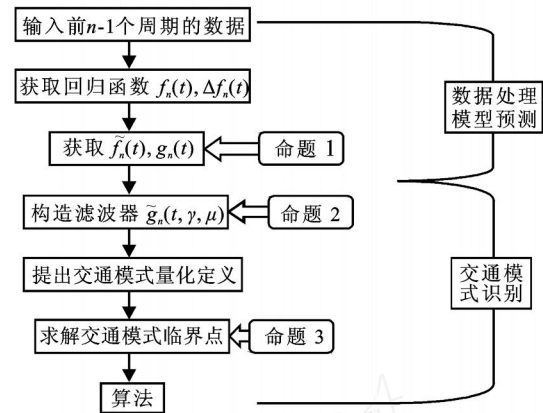


图 1 交通需求预测整体流程框图

为了建立交通需求预测的迭代学习模型, 基于上述分析现作如下假设:

- 1) 建筑物使用功能相对稳定;
- 2) 电梯交通配置满足统计特性指标要求^[8];
- 3) 乘客能够正常使用电梯呼叫系统;
- 4) 交通需求近似地呈动态周期性变化;
- 5) 周期意义下交通需求近似趋于稳定状态.

基于上述假设, 构造如下电梯交通需求预测的迭代学习模型:

$$\tilde{f}_{n+1}(t) = \tilde{f}_n(t) + \frac{1}{n+1} [f_n(t) - \tilde{f}_n(t)],$$

$$n = 0, 1, \dots, t \in [0, T]. \quad (5)$$

其中: $\tilde{f}_n(t)$ 为第 n 个周期交通需求预测函数; $f_n(t)$ 为第 n 个周期实际交通需求回归函数; $f_0(t)$ 为初始交通需求函数, 且 $\tilde{f}_0(t) = f_0(t), f_0(t) \geq 0, \tilde{f}_0(t) \geq 0, f_n(t) = f_n(t) - f_{n-1}(t), \tilde{f}_n(t) = f_n(t) - \tilde{f}_n(t), n = 1, 2, \dots; T$ 为迭代周期.

根据对电梯交通需求规律的观测, 将特征近似的工作日间的最小间隔天数作为一个周期. 一般由建筑物的使用功能等一些重要因素决定, 通常取 $T = 1 \text{ d}$ 或 $T = 5 \text{ d}$ 等.

3.1 交通需求预测函数 $\tilde{f}_n(t)$ 的收敛性讨论

构造如下命题, 讨论上述模型的性质.

条件 1 $f_n(t)$ 和 $\tilde{f}_n(t) (n = 0, 1, \dots)$ 为 $[0, T]$ 上一致有界且连续可微的函数.

条件 2 $f_n(t)$ 在 $[0, T]$ 上一致收敛.

命题 1 若条件 1 和条件 2 成立, 则有:

- 1) $\tilde{f}_n(t)$ 在 $[0, T]$ 上一致收敛于 $\tilde{f}(t)$, 这里

$$\tilde{f}(t) = \lim_{n \rightarrow \infty} \frac{1}{n+1} \sum_{k=0}^n f_k(t); \quad (6)$$

- 2) $\tilde{f}(t)$ 在 $[0, T]$ 上连续可微.

证明略.

由命题 1 的结论知: 在实际应用中, 若经 p 个

周期的预测函数无明显变化,便可认为得到了电梯交通运行规律.不妨取 $\tilde{f}(t) = \tilde{f}_n(t), \exists N > 0, \forall n > N$.

3.2 滤波器构造及其性质

实际的观测数据往往会受到随机因素的影响,使预测函数 $\tilde{f}_n(t)$ 的形式比较复杂.下面通过构造滤波函数,采用滤波方法进一步处理电梯交通需求的干扰因素,获得交通需求的主要信息.

定义1 令 $\tilde{f}_n^u(t)$ 和 $\tilde{f}_n^d(t) (n = 0, 1, \dots)$ 分别为第 n 个周期的上行和下行预测函数,且在 $[0, T)$ 上连续可微.若取函数

$$g_n(t) = \tilde{f}_n^u(t) - \tilde{f}_n^d(t), \quad (7)$$

则称 $g_n(t)$ 为电梯交通需求差函数(简称差函数).

注1 定义电梯交通需求差函数的目的是综合处理电梯交通需求中上行和下行两方面信息,并据此讨论模式识别问题.

定义2 若取

$$\tilde{g}_n(t, \mu) = g_n(t) e^{(g_n^2(t) - \mu^2)}, \quad n = 1, 2, \dots, \mu > 0, \quad (8)$$

则称 $\tilde{g}_n(t, \mu)$ 为 $g_n(t)$ 的滤波函数,其中 μ 为参变量.

命题2 已知 $g_n(t)$ 为电梯交通需求差函数, $\tilde{g}_n(t, \mu)$ 为 $g_n(t)$ 的滤波函数,则有:

- 1) $\tilde{g}_n(t, \mu)$ 与 $g_n(t)$ 有相同的单调性,且

$$\lim \tilde{g}_n(t, \mu) = \begin{cases} +, & g_n(t) > \mu; \\ -, & g_n(t) < -\mu; \\ g_n(t), & |g_n(t)| = \mu; \\ 0, & |g_n(t)| < \mu; \\ n = 1, 2, \dots \end{cases} \quad (9)$$

2) $\tilde{g}_n(t, \mu)$ 是 $[0, T) \times (0, +\infty) \times (0, +\infty)$ 上的连续可微函数,且

$$\frac{\partial \tilde{g}_n(t, \mu)}{\partial t} = g_n(t) e^{(g_n^2(t) - \mu^2)} [1 + 2g_n^2(t)]. \quad (10)$$

显然, $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 与 $g_n(t)$ 也有相同的单调性,并满足:若 $g_n(t) > 0$,则有

$$\lim \frac{\partial \tilde{g}_n(t, \mu)}{\partial t} = \begin{cases} 0, & |g_n(t)| < \mu; \\ +, & |g_n(t)| > \mu. \end{cases} \quad (11)$$

若 $g_n(t) < 0$,则有

$$\lim \frac{\partial \tilde{g}_n(t, \mu)}{\partial t} = \begin{cases} 0, & |g_n(t)| < \mu; \\ -, & |g_n(t)| > \mu. \end{cases} \quad (12)$$

由单调性的定义易证命题2成立.证明略.

由命题2的结论知:

1) 滤波函数 $\tilde{g}_n(t, \mu)$ 保留了差函数 $g_n(t)$ 的两个重要信息: $g_n(t)$ 的基本变化趋势(见结论1)) 和变化率 $g_n(t)$ 的基本变化趋势(见结论2)) 的信

息.

2) 通过对函数 $\tilde{g}_n(t, \mu)$ 和 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 关于变量 t 的变化规律的讨论,可知当参变量 μ 取值大于某个数时,便可很好地控制 $\tilde{g}_n(t, \mu)$ 和 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 的变化.实际上,为了有效控制 $g_n(t)$ 和 $g_n(t)$ 的信息,只需控制 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 的变化即可.因此将函数 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 在 $[0, +\infty)$ 上变化最快的时间点作为交通模式变更的临界点.

3.3 电梯交通模式区间识别及性质分析

定义3 当给定参数 μ 时,若 $t_i^* (t_i^* > 0, i = 1, 2, \dots, q)$ 为方程

$$\frac{\partial^2 \tilde{g}_n(t, \mu)}{\partial t^2} = 0 \quad (13)$$

所有不同的正实根,则称 $t_i^* (i = 1, 2, \dots, q)$ 为电梯交通模式的敏感点.

定义4 当给定常数 k 时,则称满足

$$|\frac{\partial \tilde{g}_n(t_i^*, \mu)}{\partial t} H T 3, 6 S S| \geq k \quad (14)$$

交通模式的敏感点 t_i^* 为电梯交通模式的临界点.

由上述定义可知: $t_i^* (t_i^* > 0, i = 1, 2, \dots, q)$ 包含了函数 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 关于变量 t 的所有极值点,即一定包含 $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 在 $[0, +\infty)$ 上变化最快的所有点.因此,模式临界点是这些变化最快的点中满足 $\frac{\partial \tilde{g}_n(t_i^*, \mu)}{\partial t} \geq k$ (常数) 的点 t_i^* .下面讨论如何求 t_i^* .

命题3 当给定参数 μ 时,方程 $\frac{\partial^2 \tilde{g}_n(t, \mu)}{\partial t^2} = 0$ 与

$$g_n(t) [1 + 2g_n^2(t)] + 2g_n(t) [3 + 2g_n^2(t)] (g_n(t))^2 = 0 \quad (15)$$

同解.

由导数性质易证,具体证明略.

显然,求解方程(15)即可获取所有的电梯交通模式临界点,进而完成对交通模式的识别.

以上讨论中出现了3个参数 μ, k , 简要分析如下: 在命题2中,已给出了参数 μ 的意义.值得注意的是: 随着参数 μ 的增加,当 $g_n(t) > \mu$ 时, $\frac{\partial \tilde{g}_n(t, \mu)}{\partial t}$ 将逼近于零,因此只要给出一个比较大的正数 k ,就能使差函数 $g_n(t)$ 大于 μ ,并把具有较大变化率的电梯交通模式临界点鉴别出来,进而获取不同的交通模式.

以上由观测数据集利用 LS-SVM 技术得到回归函数 $f_n(t)$,再用迭代学习理论获取预测模型 $\tilde{f}_n(t)$,基于 $\tilde{f}_n(t)$ 构造滤波函数,实现模式识别.

4 第 n 个周期的模式识别算法

1) 输入训练样本集

$$T_k = \{(t_{1k}, x_{1k}), (t_{2k}, x_{2k}), \dots, (t_{lk}, x_{lk})\} \quad (T \times X)^l.$$

其中 l 为样本总数, $(t_{ik}, x_{ik}) \in R^2$. 利用 LS-SVM 计算 $f_k(t), k = 1, 2, \dots$

2) 迭代学习

$$\tilde{f}_{n+1}(t) = \tilde{f}_n(t) + \frac{1}{n+1} [f_n(t) + \tilde{f}_n(t)],$$

$$n = 0, 1, \dots, t \in [0, T).$$

3) 由 2) 计算出第 n 个周期的电梯交通需求差函数 $g_n(t)$ 及滤波函数 $\tilde{g}_n(t)$.

4) 给定 μ 求解方程 (15), 获取交通模式的敏感点 $t^* = t_1^*, t_2^*, \dots, t_q^*$, 其中 $t_1^* < t_2^* < \dots < t_q^*$; 再由条件 $|\frac{\partial \tilde{g}_n(t_i^*, \mu)}{\partial t}| = k$ (k 为常数) 确定交通模式临界点.

5 仿真实验

交通观测数据取自某办公建筑. 根据通用的研究方法, 每 5 min 采集一个交通数据^[1,6,9], 每天 7:00 ~ 19:00 共 144 组数据, 采集时间为某周 1 ~ 周 5, 餐厅在底层. 基于实验选取 Gauss RBF 作为核函数, 取 $\sigma^2 = 0.005, C = 327$. 用周 1 ~ 周 4 的观测数据作为训练集来预测周 5 的交通需求状况.

本文提出的方法与 BP 神经网络方法 (BPNN) 进行比较, 图 2 和图 3 为预测误差曲线, 图 4 和图 5




图 2 LS-SVM 上行交通预测误差曲线




图 3 LS-SVM 下行交通预测误差曲线




图 4 BPNN 上行交通预测误差曲线




图 5 BPNN 下行交通预测误差曲线

表 1 LS-SVM 与 BPNN 预测精度 (e_{MSE}) 的比较

预测方法	上行交通	下行交通
LS-SVM	4.410 5	3.642 3
BPNN	5.322 5	4.581 7

为采用 BPNN 所得误差曲线. 采用文献 [5] 的均方根误差 (e_{MSE}) 方法对两种方法的预测精度进行比较, 结果见表 1. 主要交通模式仿真结果如表 2 所示.

仿真结果表明: 基于 LS-SVM 支持向量机的迭代学习预测结果, 能较好地反映实际交通状况, 为利用滤波函数识别交通模式奠定了基础. 在足够观测数据及合理确定迭代周期的基础上, 实际值与预测值之间的误差将随着迭代学习的进行而逐步缩小. 因午餐上高峰强度较小, 未能获取其交通模式预测结果 (见表 2), 这与文献 [10] 的研究结果极为相似. 原因是一些员工到外边用午餐, 或楼内人员午餐后离开大楼, 使午餐上高峰交通需求相对分散. 这说明建筑物功能直接影响交通模式强度. 另外, 在确定其他主要交通模式的前提下, 适度调整 μ 可近似获取强度较弱的午餐上高峰交通模式. 在其强度较弱的情况下, 从群控调度策略选择的角度, 在一定范围内可划归到层间交通处理.

表 2 主要交通模式区间的仿真结果 (周 5)

	上高峰模式区间	午餐下高峰模式区间	下高峰模式区间
仿真预测	7:49 59 ~ 9:06 39	11:25 00 ~ 12:06 40	17:13 20 ~ 18:11 39
实际情况	7:48 20 ~ 9:06 40	11:21 40 ~ 12:08 20	17:10 00 ~ 18:13 20

注: 就本文所采用观测数据而言, 其余时间可按层间交通模式处理. 其中参数: $\sigma = 10, \mu = 20, k = 10$.

(下转第 309 页)

本文讨论的是确定系统的情况,对于不确定系统的情况将另文给出.

参考文献(References)

- [1] Milosavljevic D. General conditions for the existence of a quasi-sliding mode on the switching hyperplane in discrete variable structure systems [J]. Automatic Remote Control, 1985, 46(3): 307-314.
- [2] Dot Y, Holf R G. Microprocessor based sliding mode controller for DC motor drives [C]. The Industrial Application Society Annual Meeting. Cincinnati, 1980, 2: 154-161.
- [3] Sapturk S Z, Istefanopulos Y, Kaynak O. On the stability of discrete-time sliding mode control systems [J]. IEEE Trans on Automatic Control, 1987, 32(10): 930-932.
- [4] Furuta K. Sliding mode control of a discrete systems [J]. Systems and Control Letters, 1990, 14(2): 145-152.
- [5] 高为炳. 离散时间系统的变结构控制[J]. 自动化学报, 1995, 21(2): 154-161.

- (Gao Wei-bing. Discrete-time variable structure control [J]. Acta Automatic Sinica, 1995, 21(2): 154-161.)
- [6] 高为炳. 变结构控制的理论及设计方法[M]. 北京: 科学出版社, 1998.
(Gao Wei-bing. Theory and design methods of variable structure control[M]. Beijing: Science Press, 1998.)
- [7] 姚琼荃, 宋立忠, 温洪. 离散变结构控制系统的比例-等速-变速控制[J]. 控制与决策, 2000, 15(3): 329-332.
(Yao Qiong-hui, Song Li-zhong, Wen Hong. Proportional-constant-variable rate control of discrete-time variable structure systems [J]. Control and Decision, 2000, 15(3): 329-332.)
- [8] 李文林. 离散时间系统变结构控制的趋近律问题[J]. 控制与决策, 2004, 19(11): 1267-1270.
(Li Wen-lin. Reaching law of discrete-time variable structure control systems [J]. Control and Decision, 2004, 19(11): 1267-1270.)
- [9] Hung J Y, Gao W B, Hung J C. Variable structure control: A survey [J]. IEEE Trans on Industrial Electronics, 1993, 40: 2-22.

(上接第 305 页)

6 结 语

本文提出的交通需求的智能化迭代学习方法,具有可靠的理论依据,为获取交通需求动态变化规律提供了简单可行的方法.对经典交通需求模式的概念进行扩展,提出的交通模式识别的滤波函数方法,为交通需求模式量化求解的研究奠定了理论基础.仿真实验表明,所得结果能较好地逼近实际情况,说明所提出的方法是正确而可行的.

参考文献(References)

- [1] Barney G C, Dos Santos S M. Elevator traffic analysis: Design and control [M]. London: IEE Peter Peregrinus Ltd, 1985.
- [2] 杨祯山, 邵诚. 电梯群控技术的现状与发展方向[J]. 控制与决策, 2005, 20(12): 1321-1331.
(Yang Zhen-shan, Shao Cheng. On the present situation and developing trends of elevator group supervisory control technologies[J]. Control and Decision, 2005, 20(12): 1321-1331.)
- [3] Huang M, Xu L, Wang J H, et al. Predictive method for traffic flow of elevator systems based on neural networks[C]. Proc of the 4th Conf on Control and Automation. Montreal, 2003: 683-687.
- [4] Li X, Tong L, Zong Q. ARMA model for elevator traffic flow forecasting [J]. Elevator World, 2005, 53

- (8): 83-87.
- [5] 宗群, 岳有军. 电梯群控系统交通流的预测方法[J]. 系统工程与电子技术, 2001, 23(7): 103-105.
(Zong Qun, Yue You-jun. A traffic flow forecasting method of elevator group control system[J]. Systems Engineering and Electronics, 2001, 23(7): 103-105.)
- [6] Barney G C. Elevator traffic handbook [M]. London: Spon Press, 2003.
- [7] Suykens J A K, Van Gestel T, De Brabanter J, et al. Least squares support vector machines[M]. Singapore: World Scientific Publishing Co, 2002.
- [8] 朱德文, 付国江. 电梯群控技术[M]. 北京: 中国电力出版社, 2006.
(Zhu De-wen, Fu Guo-jiang. Elevator group control technology[M]. Beijing: China Electric Power Press, 2006.)
- [9] Barney G C. Traffic design benchmarks standard templates[J]. Elevator World, 2005, 53(2): 79-82.
- [10] 李中华, 朱燕飞, 李春华, 等. 基于人工免疫聚类算法的电梯交通流分析[J]. 华南理工大学学报, 2003, 31(12): 26-29.
(Li Zhong-hua, Zhu Yan-fei, Li Chun-hua, et al. Elevator traffic flow analysis based on artificial immune clustering algorithm[J]. J of South China University of Technology, 2003, 31(12): 26-29.)